

### DNNを用いた初期波形推定による単板磁気特性試験用磁束波形制御の高速化に関する研究

角, 和樹 / SUMI, Kazuki

---

(出版者 / Publisher)

法政大学大学院理工学研究科

(雑誌名 / Journal or Publication Title)

法政大学大学院紀要. 理工学研究科編

(巻 / Volume)

64

(開始ページ / Start Page)

1

(終了ページ / End Page)

8

(発行年 / Year)

2023-03-24

(URL)

<https://doi.org/10.15002/00026358>

# DNN を用いた初期波形推定による 単板磁気特性試験用 磁束波形制御の高速化に関する研究

SPEEDUP OF FLUX WAVEFORM CONTROL BASED ON DEEP NEURAL NETWORK  
IN SINGLE SHEET TESTER

角 和樹

Kazuki SUMI

指導教員 岡本 吉史

法政大学大学院理工学研究科電気電子工学専攻修士課程

To achieve high efficiency of various motors, the realization of the high saturation magnetic flux density and thinning of the electrical steel sheets are required. When the performances of various motors are verified using the finite element method (FEM), the accurate magnetic property of the electrical steel sheet is applied to FEM. However, because extended elapsed time is taken to measure the magnetic property in the high flux region when the conventional feedback control is applied to the flux waveform control, the method for reducing the measurement time is essential. In this paper, a waveform control method that evaluates the initial waveform using a deep neural network (DNN) is proposed. The performance of the proposed system supported by the DNN is verified and compared to that supported by only the conventional feedback formula.

**Key Words** : electrical steel sheet, high magnetic flux density, single sheet tester, method of waveform control, deep learning

## 1. はじめに

近年、エネルギーの安定供給の確保や地球環境保護の観点から、省エネルギー化の需要が一層増加しており、自動車産業では、ガソリン車からハイブリッド・電気自動車への転換が進んでいる。高効率・高出力モーターの開発には、様々な特性が要求されるが、特に、発進・加速時には、高トルクが必要となるため、駆動電流を大きくし、巻線と鎖交する磁束を大きくする必要がある<sup>[1], [2]</sup>。そのため、モーターの主要鉄芯材料には、高磁束密度の特性を有する電磁鋼板が求められている<sup>[3]</sup>。

電磁鋼板の有力な磁気特性試験法として単板磁気特性試験法があり<sup>[4]</sup>、磁気特性データを用いて、材料評価や有限要素法 (FEM) による磁界解析の観点から設計技術に広く使用されている。通常、当該試験法での測定は、高磁束密度領域においては、磁束正弦波条件を満たすために、磁束波形制御 (磁束正弦波制御) が行われる<sup>[5], [6]</sup>。これにより、回路定数の差異に依存しないように考慮した励磁条

件同一での高磁束密度領域における透磁率や鉄損などの磁気特性を精確に測定する。

しかし、当該試験法での測定において、高磁束密度領域では、基本波に対して高調波成分を多く含む歪波電圧を印加することで、磁束正弦波条件を満たす必要がある<sup>[7]</sup>。このため、高磁束密度領域での波形制御法 (従来法)<sup>[8]</sup>では、励磁電圧波形を反復修正する際に、フィードバック回数が著しく増加し、測定時間の増大が懸念される<sup>[9], [10]</sup>。また、特に渦電流の影響が小さく、直流磁気特性とみなせる 5 Hz 以下の超低周波帯での高磁束密度領域においては、誘導起電力波形が著しく歪み、磁束正弦波条件を満たすのは難しくなるため、波形制御にかかるフィードバック回数が更に増加する傾向にある。

そこで本稿では、Deep Neural Network (DNN)<sup>[11]</sup>を用いて励磁電圧波形を初期波形として推定するデジタル方式の波形制御法を提案する。初期波形推定は、フィードバック回数の低減による波形制御の高速化により、測定時間の短縮を行うことができる。さらに、歪率をフィードバック

ク開始前から収束値付近に制御することから、今まで支配的であった任意の係数などに依存しづらくなり、収束計算の安定性が向上する。あらかじめ、実測した学習データを用意し、磁気特性データ量の拡張を行うことで、DNNのモデルを構築した。少数の学習データからデータの拡張をし、ラベル付けのコストを低減した効率的な学習を行うことで、実用的な側面から検証を行った。また、特に歪率が増加傾向にある超低周波に適用できるようなモデル構築が可能であるのか実用的な面で、重要な点に関して、基礎検討を行った。その結果、1 Hzの波形制御時に提案手法の初期波形推定を行った際に、測定時間の高速化を行うことが可能となり、有用性が確認されたので報告する。

## 2. 磁気特性測定手法

### (1) Hコイル法

本論文では、磁界算出手法として、試料から直接磁束を検出し、誘導起電力から磁界の強さを求めるHコイル法<sup>[12]</sup>を使用した。磁界の強さ $H$ の算出式を(1)式に示す。

$$H(t) = -\frac{1}{\mu_0 N_H S_H} \int_{t_0}^{t_0+t_n} v_H(t) dt \quad (1)$$

$\mu_0$ は真空の透磁率、 $N_H S_H$ はHコイルのエリアターン、 $v_H$ はHコイルの誘導起電力波形、 $t_0$ は積分開始点、 $t_n$ は積分終点である。Hコイルのエリアターンは、電圧印加時の励磁巻線枠とHコイルとの比から計算した。

### (2) 磁束密度算出手法

試料に直巻きしたBコイルから得られる誘導起電力 $v_B$ を磁束密度 $B$ への算出式を(2)式に示す。

$$B(t) = -\frac{1}{N_2 S_B} \int v_B(t) dt \quad (2)$$

ここで、 $N_2$ はBコイルの巻き数、 $S_B$ は試料の断面積である。

### (3) 歪波に対するフーリエ級数展開

測定回路内、機器既存のノイズが、測定されたHコイル誘導起電力波形、Bコイル誘導起電力波形、印加電圧の各波形が歪み、測定再現性が懸念される。よって、フーリエ級数展開を適用して高精度な測定波形の実現に試みた。各測定波形を総称して $v$ とおき、測定波形の対称性により、奇数調波成分のみを考慮した。(3)式に歪波交流に対するフーリエ級数展開式を示す。

$$v(t) = \sum_{k=0}^{N_{\max}} (a_{2k+1} \sin(2k+1)\omega t + b_{2k+1} \cos(2k+1)\omega t) \quad (3)$$

ここで、 $k$ 、 $N_{\max}$ は、それぞれ調波次数及び最大調波次数を決定する変数であり、 $a_{2k+1}$ 、 $b_{2k+1}$ は測定した各波形データから得られる奇数次調波における奇関数及び偶関数のフーリエ係数、 $\omega$ は角周波数である。

## 3. 磁気特性測定システム

### (1) 単板磁気試験器 (SST)

図1(a)、(b)に単板磁気特性試験器の構造と主要寸法を示す。経済性の観点から、励磁巻線と試料の枠の寸法を

日本産業規格 (JIS)<sup>[13]</sup>の約60%に縮小している。測定試料は、無方向性電磁鋼板 (35A300,50A1300)を用いた。励磁コイルには、ポリエステル銅線 $\phi 1$  mmを1層当たり167 turnで22層、合計3674 turnの巻線を施した。磁束密度測定用のBコイルには、ポリウレタン銅線 $\phi 0.1$  mmを21 turnの巻線を施した。Hコイルには、均一磁場が得られる試料幅の約90%の範囲に、ポリウレタン銅線 $\phi 0.04$  mmを1481 turnの巻線を施した。また、ヨークには、方向性電磁鋼板 (23JGH090)を用いて、縦型複ヨークとして使用した。

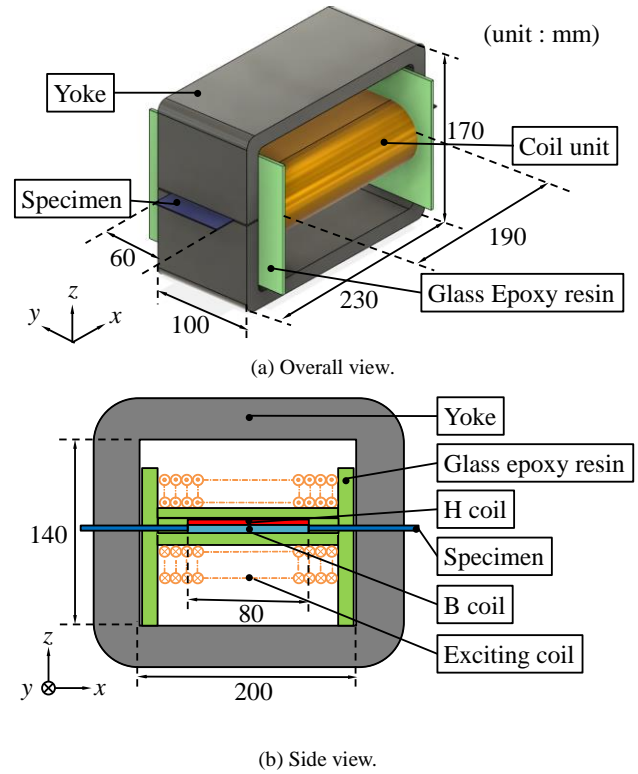


Fig. 1. Single sheet tester.

### (2) 測定システム

図2にLabVIEWで設計した計測ディスプレイを示す。DNNの学習データを構築するモデルは、バックエンドとしてTensorflow<sup>[14]</sup>、フロントエンドとしてKeras<sup>[15]</sup>を学習のフレームワークとして用いたPythonを機械学習用として、LabVIEWを磁気測定用として統合し、測定システムに実装した。

図3にSSTによる磁気特性測定システムを示す。測定システムは、PCに接続されたD/A変換器とA/D変換器を使用して、LabVIEWによって図2のコントロールパネルを用いて制御する。HコイルとBコイルで出力された誘起電圧波形は、64回の測定波形を平均化してPCに転送した。また、ノイズの影響を除去するために、A/D変換後の測定波形に対して、フーリエ級数展開を行い、偶数調波と励磁周波数の52次以上の高調波成分をソフトウェア上で除去を行った。その後、LabVIEWで収束条件を満たすまで、磁束密度波形制御を行った。

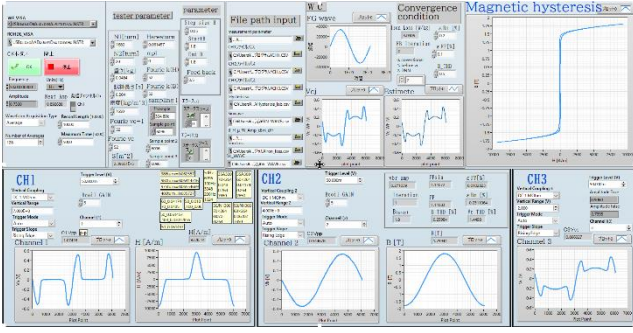


Fig. 2. Measurement display designed using LabVIEW.

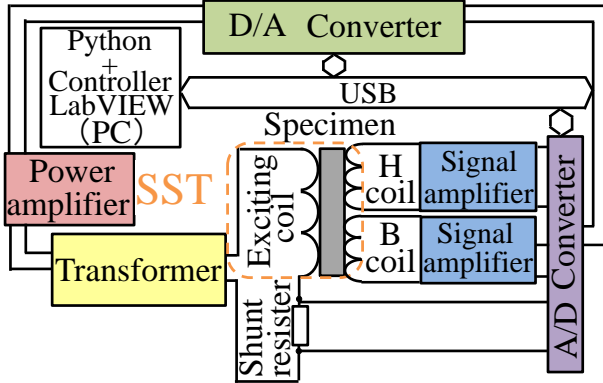


Fig. 3. Measurement system using SST.

#### 4. 波形制御法(従来法)

学習データ作成と初期波形推定後に用いる負帰還のデジタルフィードバック制御では、磁束正弦波条件を満たすまで、過小緩和法に基づく単純修正方程式による波形制御法<sup>[16]</sup>を採用した。D/A 変換器(ファンクションジェネレータ)から発生させた印加波形の電圧と B コイルの誘導起電力の基本波成分の比に着目した波形制御法を B コイルの目標電圧波形である正弦波に漸近するまで、フィードバックを繰り返し、使用した。その波形制御式を以下に示す。

$$v_c^{(j+1)}(t) = v_c^{(j)}(t) - K \frac{V_{cl}^{(j)}}{V_{Bl}^{(j)}} (v_B^{(j)}(t) - v_{Br}^{(j)}(t)) \quad (4)$$

ここで、 $v_c$  は、D/A 変換器で発生させた印加電圧、 $v_B$  は、B コイルの誘起電圧、 $V_{cl}$ 、 $V_{Bl}$  は、 $v_c$  と  $v_B$  波形の基本波成分、 $V_{Br}$  は、目標磁束密度波形(正弦波)、 $K$  は、フィードバック係数(任意定数)、 $j$  は、フィードバック回数である。なお、フィードバック時には、 $v_c$  にもフーリエ級数展開を適用し、52 次以上の高調波成分を除去することで、フィードバック更新時に  $v_B$  に含まれるノイズ成分の影響を除去した。

#### 5. DNN による初期波形推定を用いた波形制御法

##### (1) DNN で使用する学習データ

学習データとして、35A300 (RD) の実測データを使用する。実測データは、高磁束密度領域の目標磁束密度 1.5 T から 2.0 T (0.05 T 刻み) の波形制御開始前の  $v_B$  波形と波形制御終了後の  $v_c$  波形のデータである。これに、THD が収束値である 0.5 % 以下である  $v_B$  と  $v_c$  の波形データを合わせて、学習データのベースとした。なお、グレードの異なる無方

向性電磁鋼鉄でも適用可能か検討するために学習で使用する波形データはすべて正規化を行ったデータである。学習データとなる計測値から、効率的に学習データ数を増やすために、前処理として、目標磁束密度である実測データ間の補間を 3 次スプライン関数<sup>[17]</sup>を使用することで、データの拡張を行った。

図 4 に実測データからデータの拡張を行った例を示す。拡張後の学習データは、12 個のそれぞれの実測データ間を 500 個ずつの補間を行う。これにより THD が約 0.5 % から約 20 % の  $v_B$  波形データに対応した  $v_c$  波形データのセット約 5500 個であり、波形制御開始時の  $\epsilon_{Bm}$  に大きく依存しない。なお、補間に必要な係数は、LabVIEW のスプライン補間 vi で自動計算されるようにすることで、学習データの前処理および測定時間を削減した。

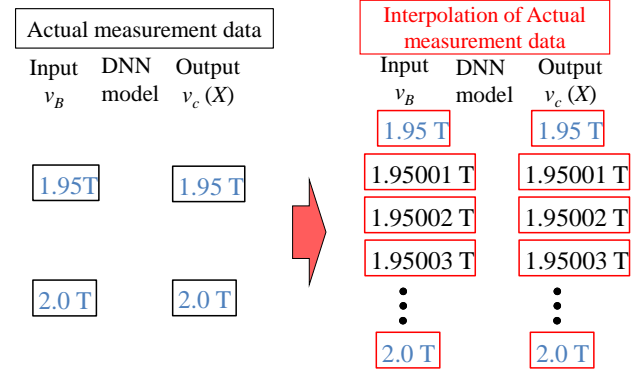


Fig. 4. Expansion of training data.

##### (2) DNN の概要

図 5 に DNN の概要図を示す。DNN の入力値に、前章の補間後の B コイルの誘導起電力波形 ( $v_B$ ) のフーリエ級数展開を行った基本波から第 51 次までの奇数次調波成分の振幅値 ( $v_{B1} \sim v_{B51}$ ) を入力データとし、入力データ  $v_B$  は、以下のように定義される

$$v_B(t) \approx \sum_{k=0}^{N_{\max}} V_{B(2k+1)} \sin((2k+1)\omega t + \theta_{B(2k+1)}) \quad (5)$$

ここで、 $N_{\max}$ 、 $V_{B(2k+1)}$  および  $\theta_{B(2k+1)}$  はそれぞれ、最大調波次数、B コイルの誘導起電力波形の振幅値、位相角である。出力データは、収束後の印加電圧波形 ( $v_c$ ) の離散コサイン変換 (DCT-II)<sup>[18]</sup>を行った 1 次から 200 次までの周波数成分の要素 ( $X_1$  から  $X_{200}$ ) である。DNN の予測モデルからの出力値に対して、逆 DCT 変換を行うことで推定した初期波形として使用する。出力データ  $X$  は、以下のように定義される。

$$X_m = \sqrt{\frac{2}{N}} k_m \sum_{n=0}^{N-1} x_n \cos\left\{\pi\left(n + \frac{1}{2}\right)\frac{m}{N}\right\}$$

$$x_n = \sqrt{\frac{2}{N}} \sum_{m=1}^{N-1} k_m X_m \cos\left\{\pi\left(n + \frac{1}{2}\right)\frac{m}{N}\right\} \quad (6)$$

$$(n, m = 0, \dots, N-1), k_j = \begin{cases} 1 & (j=1, 2, \dots, N-1) \\ \frac{1}{\sqrt{2}} & (j=0, N) \end{cases}$$

ここで、 $N$ 、 $X_m$  および  $x_n$  はそれぞれ、測定点数、 $\text{DCT}(x_n)$  の  $m$  番目要素、元波形の  $n$  番目要素である。DCT を用いる

目的は、データ量の削減である。この入出力データの実測値を元にして、補間を行う。ここで、 $\varphi_{\beta,\alpha}$ 、 $\varphi_{(\beta-1),\gamma}$  はそれぞれ、 $\beta$  層と $(\beta-1)$ 層の  $\alpha$ 、 $\gamma$  番目のニューロンの値、 $w_{(\beta-1),\gamma}$  はニューロン  $\varphi_{(\beta-1),\gamma}$  と  $\varphi_{\beta,\alpha}$  のノード間の結合重みである。




Fig. 5. Schematic diagram of DNN.

### (3) DNN の学習

図 6 に、DNN による学習プロセスのフローチャートを示す。実測データと補間データからなるデータセット全体は、訓練データ (70%)、検証データ (20%)、テストデータ (10%) の 3 つのサブセットにランダムに分割した<sup>[19]</sup>。DNN の学習において、モデルを最適化するための損失関数  $L$  と学習モデルの性能を確認するための評価関数  $MAE$  は以下のように定義される。

$$L = \frac{1}{N} \sum_{m=1}^N (X_m - \hat{X}_m)^2 \quad (7)$$

$$MAE = \frac{1}{N} \sum_{m=1}^N |X_m - \hat{X}_m| \quad (8)$$

ここで、 $X_m$ 、 $\hat{X}_m$  および  $N$  はそれぞれ、DNN モデルの出力値において、対応する実際の測定値、推定された予測値および学習データ数である。DNN は  $L$  について誤差逆伝搬法<sup>[20]</sup>を適用することで学習する。また、未知データに対応するために Mean Absolute Error ( $MAE$ ) を予測精度指標としてモデルの評価を行う。学習で使用する活性化関数や層数、ニューロン数、最適化アルゴリズム、ドロップアウト率などのハイパーパラメータは、Preferred Networks 社の Optuna<sup>[21]</sup> を使用し、調整および最適化した。Optuna は、ハイパーパラメータチューニングをベイズ最適化<sup>[22]</sup>に基づいて行う代表的な Python のフレームワークであり、損失関数を設定し最適化を目指すことでより良いハイパーパラメータの組み合わせを探索する。

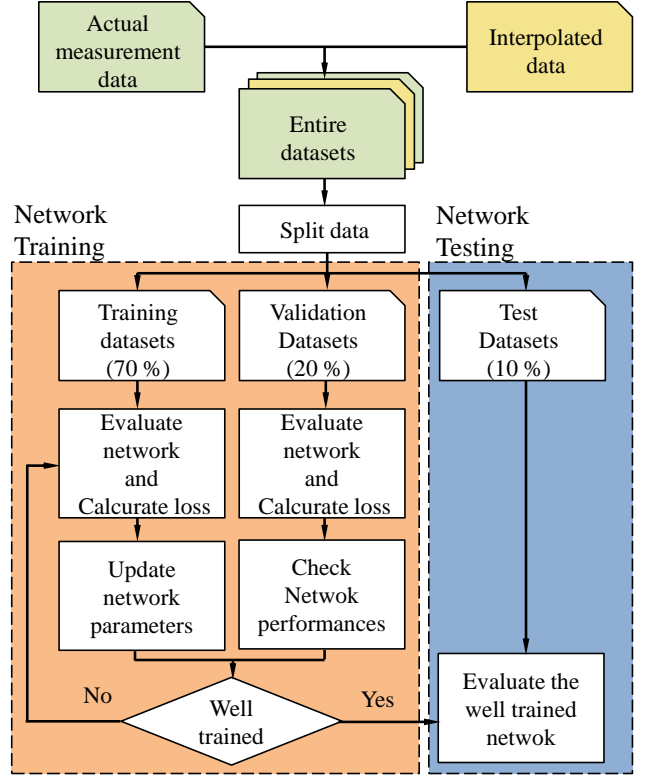


Fig. 6. Flowchart of the learning process by DNN.

### (4) DNN による初期波形推定

図 7 に、DNN による初期波形推定を用いた波形制御のフロー図を示す。DNN による初期波形推定とは、波形制御に要するフィードバック時間短縮のために、磁束正弦波条件を満たした収束時の印加電圧波形  $v_c$  を波形制御のフィードバック前に推定する方法である。これにより、フィードバック回数の低減を行うことで、高速に収束条件を満たす。初期波形推定後の波形制御に際しては、B コイルの誘導起電力波形が正弦波になるように収束条件を満たすまで、デジタルフィードバックを繰り返す。収束条件である  $\varepsilon_{FF}$  および  $\varepsilon_{Bm}$ 、 $THD$  は、以下のように定義される。

$$\varepsilon_{FF} = \frac{FF - FF_{\sin}}{FF_{\sin}} \times 100 [\%] \quad (9)$$

$$\varepsilon_{Bm} = \frac{B_m - B_0}{B_0} \times 100 [\%] \quad (10)$$

$$THD = \sqrt{\frac{\sum V_{total}^2 - V_1^2}{V_1^2}} \times 100 [\%] \quad (11)$$

ここで、 $FF$  と  $FF_{\sin}$  は誘導起電力波形と正弦波の波形率、 $B_m$  と  $B_0$  は最大磁束密度の目標磁束密度の振幅値、 $V_{total}$  と  $V_1$  は B コイルの誘導起電力  $v_B$  の基本波から第 51 次調波の振幅値の合計と基本波の振幅値を示す。それぞれ  $\varepsilon_{FF}$  が




Fig. 7. Block diagram of waveform control.

0.1%以内,  $\varepsilon_{Bm}$ が0.1%以内,  $THD$ が0.5%以内になるように制御した。

本稿では, 初期波形推定を行わない場合を Conventional Method, DNN に基づく初期波形推定を行った場合を Proposed Method とする。

## 6. 測定結果

本研究で使用した学習データのベースとなる実測データは, 35A300 (RD) の 50 Hz と 1 Hz である。従来法とそれぞれの DNN モデルで, 初期波形推定を用いた波形制御のフィードバック回数の比較を行った。

### (1) 35A300(RD)50 Hz の学習データを使用した結果

学習データと同様の試料, 周波数で DNN による初期波形推定を, 目標磁束密度  $B_m$  を 2.0 T, フィードバック係数  $K$  を 0.3 として波形制御を行った。

図 8 に 2.0 T における推定した初期波形と収束波形を示す。推定波形と収束波形の振幅値の差は, 0.061% 程度であり, 推定精度が高いことが分かる。なお, 両者の波形は, 任意波形発生装置で与える印加電圧波形であり, 印加時に正規化される。

図 9 (a), (b) に従来法と提案法の磁束波形を示す。波形制御前の磁束密度波形は, 台形波に似た波形となっているが, 波形制御によって, 励磁電圧波形を歪ませる事で, 正弦波に近似していくことが分かる。従来法では, フィードバック回数は 46 回で各波形制御条件を満たした。提案法では, 推定波形を印加した時に, 収束波形である正弦波と同様の磁束波形であることがわかる。初期波形推定後の磁束波形の  $THD$  は, 約 1% に減少し, フィードバック回数 2 回で各収束条件を満たし, 推定時の効果が確認できる。

図 10 (a), (b) に 2.0 T における DNN による初期波形推定を行った波形制御結果を示す。提案手法を 4 回試行した結果, 初期波形推定後にフィードバックが 2~3 回となり, 再現性のある波形制御の高速化が行える。また, 初期波形推定時に  $\varepsilon_{Bm}$  が波形制御開始の  $\varepsilon_{Bm}$  の誤差に応じて増加するが, 数回のフィードバックで修正可能な誤差である。

図 11 に従来法と提案手法をそれぞれ 4 回の波形制御をした結果を示す。測定再現性の検証を行うために提案法と従来法で 4 回波形制御を行った。4 回を平均した結果, 提案手法は, 従来法と比較して, 約 1/17 のフィードバックの低減により, 波形制御の高速化が確認できる。



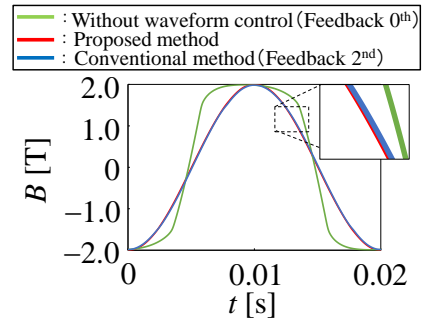


Fig. 8. Initial waveform estimation using DNN.




(a) Conventional method.



(b) Proposed method.

Fig. 9. Magnetic flux waveform.



(a) Transition of  $THD$ .

(b) Transition of  $\varepsilon_{Bm}$ .

Fig. 10. Waveform control results with the proposed method.




Fig. 11. Comparison results of waveform control between conventional and proposed method.

実際の測定では, 学習データとグレードの異なる無方向性電磁鋼板や圧延方向 (RD,TD) に依存しない初期波形推定が必要である。ここでは, 35A300 (RD) 材 50 Hz のデータを学習させたシステムが 50A1300 (RD) 50 Hz の波形制御に与える影響を検討する。

図 12 に 1.9 T における従来手法と提案手法の波形制御結果を示す。同一周波数の場合, 学習させていない材料や圧延方向であっても, 推定精度は高く, いずれも初期波形推定後は, フィードバック数回での収束が可能である。これは, グレードが変わっても入出力における各周波数成分が, 近似しているため, 高い推定精度が得られたと考えられる。




Fig. 12. Waveform control results of other materials.

表 1 に 1.7 T の各周波数における初期波形推定の効果を示す。表 1 より、学習した周波数から遠ざかると初期波形推定の効果が低下傾向にある。特に、磁束波形の THD が増大する 5 Hz 以下の超低周波では、その傾向が顕著に見られた。そのため、学習データを 1 Hz にしたモデルで 1 Hz の波形制御に適用した場合を次項で検討した。

Table 1. Effects of different frequencies on initial waveform estimation.

Frequency [Hz]	THD of magnetic flux waveform [%]	
	Before waveform control ( $\epsilon_{B_m}=0.5\%$ )	Initial Waveform Estimation
5	24.4849	12.59902
25	18.8674	3.32474
50	16.5288	0.67455
100	16.5537	3.11297

## (2) 35A300(RD)1 Hz の学習データを使用した結果

一般的に、プレイモデルの導出には、目標磁束密度の異なる多数の直流ヒステリシスを仮定した実測データから導出した形状関数を使用して、プレイモデル計算を行う必要がある。これにより、磁気ヒステリシスの高精度な模擬より、損失の定量的な算定を行うことができる<sup>[23]</sup>。よって、試料中の磁束の時間的変化を緩やかにして渦電流の影響を限りなく除去した超低周波帯の磁気特性データを用いることが望ましい。

図 13 に 1.7 T における波形制御前における磁束密度波形の THD を示す。渦電流の影響が小さく、直流磁気特性とみなせる 5 Hz 未満の超低周波帯では、特に THD が増加傾向にあり、平均化処理にも時間がかかることから、1 回あたりのフィードバックにかかる時間が増大する。したがって、波形制御の測定時間を考慮すると、超低周波帯への適用が求められる。提案手法の有用性を検証するために、目標磁束密度  $B_m$  を 1.7 T、フィードバック係数  $K$  を 0.3 とし、1 Hz のデータを学習させたシステムで 1 Hz の波形制御を行った。なお、各収束条件は、 $\epsilon_{FF}$  を 0.5 %、 $\epsilon_{B_m}$  を 0.1 %、THD を 2 % となるよう緩和して測定を行った。

図 14 に 1.7 T における従来手法と提案手法との波形制御結果を示す。図 14 に提案法を使用した磁気ヒステリシスループを示す。磁束波形が正弦波から大きくずれる超低周波帯の測定であっても、測定対象の周波数を学習すれば、推定精度が大幅に改善され、初期波形推定後のフィードバック回数は 2 回であることがわかる。

図 15 に二周波法より推定された直流ヒステリシスループと提案法を使用して測定された 1 Hz の磁気ヒステリシスループを比較した結果を示す。1 Hz の磁気ヒステリシスループは、渦電流の影響はほとんど無視できるため、推定

した直流ヒステリシスループとの差異はない。図 15 より、 $B-H$  ループの概形は一致していることから、提案法の波形制御を使用しても測定結果に影響はない。これらより、提案手法の効果が確認され、有用性があると分かる。


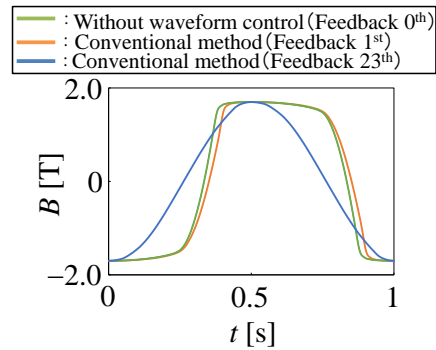
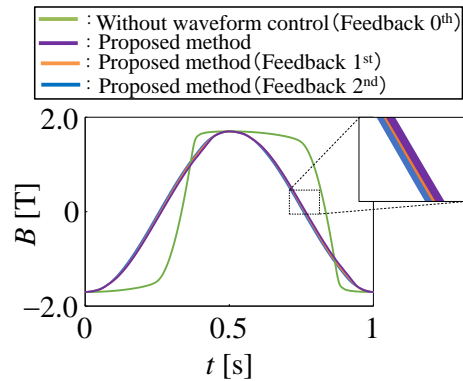



Fig. 13. THD for each frequency at the same target flux density.



(a) Conventional method.



(b) Proposed method.



(c) Comparison results of proposed and conventional method.

Fig. 14. Waveform control results at 1 Hz.




Fig. 15. Comparison results between 1 Hz  $B$ - $H$  loop and estimated  $B$ - $H$  loop.

## 7. まとめ

本論文では、DNNを用いた初期波形推定を適用した際の磁束波形制御の高速化について、検討を行った。学習モデルを作成して、低周波における同材料や他材料に適用し、従来手法と提案手法でフィードバック回数による収束特性との比較によって、提案法の性能評価を行った。本論文から得られた結果をまとめると、以下のようになる。

- (1) 波形制御の収束が悪化する低周波の測定を行った結果、学習データと同じ材料の測定を行う場合、同一周波数で提案法を使用すれば、フィードバック回数が大幅に低減することが明らかとなり、推定後のフィードバックは数回程度である。
- (2) 学習データとは、異なる周波数での測定した結果、推定後の磁束波形  $THD$  は増加傾向ではあるため、フィードバック数回で収束させるためには、係数を大きくする必要がある。そのため、推定精度をあげる場合は、近傍の周波数を学習することが望ましい。

今後、広帯域での周波数の適用を目指し、モデルの汎化性能を向上させるとともに学習データの低減に努める必要がある。

## 謝辞

本稿で述べた磁気特性および計測全般に対して、ご助言を頂いた同志社大学 石原好之 名誉教授 および 同大 藤原耕二 教授、千葉大学 宮城 大輔 教授、大分産業科学技術センター 下地広泰氏へ謝意を表します。

## 参考文献

- [1] 久保田猛：「電気自動車の駆動モータと電磁鋼板」，電気学会誌， vol. 130, no. 5, pp. 276-279 (2010)
- [2] Kunihiro Senda, Masanori Uesaka, Soichiro Yoshizaki, Yoshihiko Oda, "Electrical Steels and Their Evaluation for Automobile Motors", World Electric Vehicle Journal, vol.10, no.2, pp.31 (2019).
- [3] Ueno, M. Enokizono, Y. Mori and K. Yamazaki, "Vector Magnetic Characteristics of Ultra-Thin Electrical Steel Sheet for Development of High-Efficiency High-Speed Motor," *IEEE Trans. Magn.*, vol. 53, no. 11, pp. 1-4 (2017).

- [4] Methods of measurement of the magnetic properties of magnetic sheet and strip by means of a single sheet tester International Standard IEC 60404-3 (2010)
- [5] Y. Zhang, Y. Zhang, J. Song, X. Qi, J. Du, W. Xia, J. Zhang, A. Yan, and J. Liu, "Magnetic domain structure of Sm(Co, Cu, Fe, Zr), thick permanent magnetic films," *IEEE Trans. Magn.*, vol. 49, no. 7, pp. 3360-3363 (2013).
- [6] E. Ušák and M. Ušáková, "Fast Digital Feedback Algorithm for Efficient Control of Magnetic Flux Density Waveforms," *IEEE Trans. on Instrumentation and Measurement*, vol. 70, no. 6012108, pp. 1-8 (2021).
- [7] A. -T. Vo, M. Fassenet, A. Kedous-Lebouc, F. Blache, C. Boudinet and M. -P. Vaillant, "Novel Adaptive Controller for Effective Magnetic Measurement Under Arbitrary Magnetization," *IEEE Trans. on Industrial Electronics*, vol. 67, no. 11, pp. 9841-9850 (2020).
- [8] 上野 庄太郎, 堀 紘二郎, 藤原 耕二, 石原 好之, 戸高 敏之：「単板磁気特性試験用磁束波形制御の高速化に関する検討」，電気学会 マグネティクス研究会資料，MAG-08-79, pp. 13-18 (2008)
- [9] 中瀬知哉, 中野正典, 藤原耕二, 高橋則雄：「単板磁気試験器を用いたデジタル磁気特性システムにおける波形制御法」，電気学会論文誌 A, vol. 199-A, no. 7, pp. 1019-1025 (1999)
- [10] 上野庄太郎・藤原耕二・石原好之：「単板磁気特性試験器における低周波領域の磁気特性測定」，電気学会マグネティクス研究会資料，MAG-09-241, pp. 17 - 22 (2009)
- [11] Y. LeCun, Y. Bengio and G. Hinton, "Deep learning", *Nature*, vol. 521, pp. 436-444 (2015).
- [12] Y. Xu, X. Zhou and X. Zou, "H-Coil Measurement Method of High Performance Electrical Steel Sheet," *Proceedings of The Conference on Precision Electromagnetic Measurements*, pp. 1-3 (2018).
- [13] Methods of Measurement of the Magnetic Properties of Magnetic Steel Sheet and Strip by Means of a Single Sheet Tester, JIS C2556, Japanese Industrial Standard (2015).
- [14] <https://www.tensorflow.org/ja/>
- [15] <https://keras.io/ja/>
- [16] K. Matsubara, N. Takahashi, K. Fujiwara, T. Nakata, M. Nakano and H. Aoki, "Acceleration technique of waveform control for single sheet tester," *IEEE Trans. Magn.*, vol. 31, no. 6, pp. 3400-3402 (1995).
- [17] M. H. Schultz: *Spline Analysis* (1973) Prentice-Hall, Inc.
- [18] R. Mehta and N. Rajpal, "General regression neural network based image watermarking scheme using fractional DCT-II transform," *Proceedings of IEEE Second International Conference on Image Information Processing*, pp. 340-345 (2013).
- [19] J. Hertz, A. Krogh, B. Lautrup and T. Lehmann, "Nonlinear backpropagation: doing backpropagation without derivatives of the activation function," *IEEE Trans. on Neural Networks*, vol. 8, no. 6, pp. 1321-1327 (1997).
- [20] H. Li, S. R. Lee, M. Luo, C. R. Sullivan, Y. Chen and M. Chen, "MagNet: A Machine Learning Framework for Magnetic Core



Loss Modeling,” *IEEE 21st Workshop on Control and Modeling for Power Electronics (COMPEL)*, pp. 1-8 (2020).

- [21] <https://www.preferred.jp/ja/projects/optuna/>
- [22] J. Snoek, H. Larochelle, and R.P. Adams, “Practical Bayesian Optimization of Machine Learning Algorithms,” *Advances in Neural Information Processing Systems*, pp.2951–2959 (2012).
- [23] Y. Hosono, Y. Hane and K. Nakamura, “Hysteresis Analysis under DC-Bias by using Magnetic Circuit Model Combined with Play Model”, *Transaction of the Magnetics Society of Japan*, vol. 5, no. 1, pp. 27-31 (2021).

#### 研究業績

##### A. 国内論文・発表（査読無し，○印：発表者）

- [1] ○角和樹・岡本吉史（法政大学）・藤原耕二（同志社大学）・佐々木秀徳（法政大学）：「Deep Neural Network を用いた初期波形推定による単板磁気試験器における磁束波形制御の高速化に関する検討」，令和4年電気学会全国大会，オンライン，2022年3月
- [2] 角和樹・○岡本吉史（法政大学）・藤原耕二（同志社大学）・佐々木秀徳（法政大学）：「DNN を用いた初期波形推定による単板磁気特性試験用磁束波形制御の高速化に関する検討」，マグネティックス/モータドライブ/リニアドライブ合同研究会，MAG-22-104, MD-22-122, LD-22-075，東北大学工学研究科 総合研究棟およびオンライン，2022年11月

##### B. 国際論文・発表（査読無し，○印：発表者）

- [1] ○Sumi Kazuki, Okamoto Yoshifumi, Fujiwara Koji, Sasaki Hidenori, ” Speedup of Flux Waveforms Control Using Deep Neural Network for Single Sheet Tester,” *The 20th Biennial Conference on Electromagnetic Field Computation (CEFC)*, Denver, Colorado, Oct 2022